DOI: 10.19666/j.rlfd.202404084

基于变分模态分解的综合能源系统 短期电负荷预测

苏子越,柴 琳,谢 亮,肖 凡 (武汉科技大学信息科学与工程学院,湖北 武汉 430081)

[摘 要]针对综合能源系统负荷复杂多变、耦合性强的特点,提出一种基于变分模态分解(variational mode decomposition, VMD)、Prophet 模型、长短时记忆(long-and short-term memory network, LSTM)神经网络、差分自回归移动平均(autoregressive integrated moving average, ARIMA)模型的 Prophet-VAL 组合预测模型,用于综合能源系统短期电负荷预测。首先,通过 VMD 获取不同中心频率和较为稳定的电负荷本征模态函数;接着,根据过零率值的大小将不同模态分量分成高频和低频时序分量,并使用 Prophet 模型将高频分量进行时序特征提取;最后,通过 ARIMA 预测模型对低频分量进行预测,使用 LSTM 神经网络模型 对高频分量进行预测,将各自的预测结果进行叠加得到最终的电负荷预测结果。将所提方 法应用于实际综合能源系统,实际算例分析表明,所提出的组合预测模型预测性能良好。
 [关 键 词]综合能源系统;负荷预测;变分模态分解;LSTM 神经网络;Prophet 模型

[引用本文格式] 苏子越, 柴琳, 谢亮, 等. 基于变分模态分解的综合能源系统短期电负荷预测[J]. 热力发电, 2024, 53(12): 21-28. SU Ziyue, CHAI Lin, XIE Liang, et al. Short-term electrical load forecasting for integrated energy system based on variational mode decomposition[J]. Thermal Power Generation, 2024, 53(12): 21-28.

Short-term electrical load forecasting for integrated energy system based on variational mode decomposition

SU Ziyue, CHAI Lin, XIE Liang, XIAO Fan

(School of Information Science and Engineering, Wuhan University of Science and Technology, Wuhan 430081, China)

Abstract: Aiming at the characteristics of complex and variable load and strong coupling of integrated energy system, a combined forecasting model based on variational mode decomposition (VMD), Prophet model, longand short-term memory network (LSTM) and autoregressive integrated moving average (ARIMA) model is proposed for short-term electrical load prediction. Firstly, the electric load eigen mode functions with different center frequencies and relatively stable ones are obtained by VMD. Then, after calculating the value of zero cross rate, the modal components of each group are superimposed respectively to form the high-frequency and low-frequency timing components, and the Prophet model is used to extract the high-frequency component for timing features. Finally, the ARIMA prediction model is used to predict the low frequency component, and the LSTM neural network model is applied to predict the high frequency component. The final predicted electric load is obtained by superimposing the respective prediction results. The proposed method is applied to the actual integrated energy system, and the example analysis shows that the combined forecasting method presented above has good forecasting performance for the integrated energy system

Key words: integrated energy system; load forecasting; variational mode decomposition; LSTM neural network; Prophet model

基金项目:国家自然科学基金项目(51877161)

收稿日期: 2024-04-24

Supported by: National Natural Science Foundation of China (51877161)

第一作者简介:苏子越(1998),男,硕士研究生,主要研究方向为综合能源系统负荷分析和预测,1145176394@qq.com。

通信作者简介:柴琳(1979),男,博士,教授,主要研究方向为电力系统负荷预测、人工智能及其应用, chailin@wust.edu.cn。

综合能源系统(integrated energy system, IES) 的负荷预测对于日益增大的能源需求至关重要^[1]。 IES包括电负荷、冷负荷、热负荷等诸多负荷类型, 需要对各负荷协调规划。电力系统负荷预测可以依 据不同的时间期限划分为超短期、短期和长期负荷 预测^[2]。电力系统负荷预测的有效性和精度可以有效 保持系统稳定运行,合理安排电力调度,提高电网 运行效率^[3]。但是,短期电力负荷预测会受一些不确 定性因素的影响,IES中多种负荷间的复杂耦合关系 也使得对系统的负荷预测准确性降低。因此,研究 增强短期电力系统负荷预测的准确性至关重要。

国内外学者在负荷预测方面研究一般包括差分 自回归移动平均(autoregressive integrated moving average, ARIMA)模型^[4]、朴素预测法、简单平均 法 (moving average)、卡尔曼滤波^[5]等传统预测方法 以及支持向量回归(support vector returns, SVR)^[6]、 随机森林^[7]、径向基神经网络、极限学习机(extreme learning machine, ELM)^[8]、Prophet 模型^[9]等机器学 习方法。传统时间序列数据分析方法简单可行, Alberg 等人^[10]提出基于非季节性和季节性滑动窗口 的 ARIMA 模型, 该算法将非季节性和季节性 ARIMA 模型与在线信息网络(online information network, OLIN) 方法相结合, 实验结果表明, 该 方法在处理标准差时表现出了稳定的预测性能。罗 权[11]构建了考虑气象因素的卡尔曼滤波模型,该算 法比传统的卡尔曼滤波具有更高的预测精度。但多 元负荷容易被其他诸多条件影响,如天气、国民经 济、节假日等,线性方法难以评估短期电力负荷预 测中不稳定和随机因素的影响,无法保证预测的有 效性。与传统时间序列数据分析方法相比,机器学 习方法在解决非线性问题时更为可靠。滕爱国等[12] 从稀疏性和鲁棒性的角度对 LS-SVR 算法进行改进, 实验结果表明,改进的 LS-SVR 算法具有较高的预 测精度。Zhang 等人[13]提出了一种基于 IGSA-ELM 算法的负荷预测模型,该模型引入了 PSO 的记忆和 社会信息思想,实验结果表明,该方法在预测速度 和精度方面都有较好的表现。但面对特征维度更多、 数据复杂度更高的问题时机器学习方法仍表现出处 理速度较慢的缺点。

由于上述方法中存在的不足,国内外学者越来越多的选择结合多种预测模型以提高预测精度的组合预测方法。陆继翔等^[14]提出了一种卷积神经网络(convolutional neural network,CNN)和长短时

记忆(long-and short-term memory, LSTM)神经网 络相结合的组合预测模型,先采用 CNN 对特征向 量进行提取,再利用 LSTM 神经网络进行短期负荷 预测,结果表明该方法比单一预测方法的预测效果 更好。Yousaf 等人^[15]提出了一种基于机器学习的住 宅负荷智能低频模型,并通过主成分分析(principal component analysis, PCA)获得特征的最佳适应度 得分,然后提出了一种独特的决策集成策略,该策 略在减少预测误差方面具有显著成效。丁美荣等^[16] 提出通过采用融合 *t* 检验的经验模态分解将序列分 为高频分量和低频分量,对高频分量使用传统 STL 序列分解方法进一步对数据做处理,对高频、低频 分量分别进行 Prophet 预测。上述文献在研究负荷 预测时均将分解得到的时序分量作为预测对象,未 考虑将分解得到的时序分量作为特征输入。

2024 年

相较于将分解得到的时序分量作为预测对象 的传统研究方法,使用 Prophet 模型将分解得到的 时序分量作为负荷预测的输入特征,可以更好地分 析复杂时序数据的深层非线性关系,极大限度地保 留预测结果的时序相关性。基于此,本文在现有研 究成果的基础上,考虑综合能源系统负荷复杂多 变、耦合性强等特点,提出一种基于变分模态分解、 Prophet 模型、差分自回归移动平均模型和长短时记 忆神经网络模型的组合预测模型。首先,通过变分 模态分解来获取不同中心频率和较为稳定的本征 模态函数;接着,根据过零率值的大小将不同模态 分量分成高频和低频时序分量,并使用 Prophet 模 型将高频分量进行时序特征提取;最后,通过 ARIMA 预测模型对低频分量进行预测,使用 LSTM 神经网络模型对高频分量进行预测,将各自的预测 结果进行叠加得到最终的预测结果。

1基于变分模态分解的组合预测模型

1.1 变分模态分解

变分模态分解(variational modal decomposition, VMD)是 2014 年提出的一种非线性信号自适应的模态分解方法,此模型认为所有复杂的非线性信号都可 以分解为若干个较为简单平滑的本征模态函数 (intrinsic mode function, IMF)^[17-19]。变分模态分解 通过使较为复杂的时序变量变得更加平稳,从而提取 出许多较为稳定的模态分量。这种方法在处理随机性 较强且稳定性较差的信号分解时表现出显著优势。

为了细致分析多元负荷间的相关性和耦合性,

将多元负荷应用 VMD 方法分解为若干较为平稳的 本征模态分量。如果为每个本征模态分量建立单独 的预测模型,不仅会显著增加运算量和运算时间, 还可能导致模型误差叠加,从而影响预测模型的效 果。本文根据各个模态分量的中心频率进行考察, 将各组模态分量根据过零率的值分为线性平稳性 好的低频分量和较为复杂多变的高频分量。

过零率 Rzc 为样本过零次数与数据采样间隔 之比:

$$R_{\rm ZC} = \frac{N_{\rm ZC}}{A} \tag{1}$$

式中: N_{ZC} 为样本过零次数; A 为数据采样间隔。 1.2 ARIMA 模型

ARIMA 模型是一种应用较为广泛的时间序列 分析方法,在处理线性平稳数据时具有较为明显的 优势^[20-21]。其基本原理为:将非线性时间序列转化 为线性时间序列,接着根据自相关系数和参数估计 准则来确定模型中的参数,然后利用建立的模型进 行预测。ARIMA 模型是利用先前实际发生的结果 对未来相关值的预测,一般可表示为 ARIMA(*p*, *q*, *d*),*d* 为差分阶数,相关公式为:

 $x_t = \varphi_1 x_{t-1} + \dots + \varphi_p x_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q}$ (2) 式中: $\varphi_1, \dots, \varphi_p$ 为时间序列系数:p为时间序列阶数; ε_t 为白噪声分量; $\theta_1, \dots, \theta_p$ 为移动平均系数;q为移 动平均阶数。

ARIMA 模型具有相对简单的构造和较少的模型参数,这使得其预测速度较快。然而,它主要适用于线性和周期性的数据,对于复杂的非线性数据,其预测效果较差。故本文采用 ARIMA 模型对经过处理后相对平稳且具有一定周期性的低频分量展开预测分析。

1.3 LSTM 神经网络模型

LSTM 神经网络的核心思想在于采用门控机制 来选择性地记忆或遗忘信息,并管理记忆单元的状态更新。这种门控机制通过控制信息的流动,显著 缓解了传统循环神经网络中常见的梯度消失问题。 具体来说,LSTM 神经网络通过引入输入门、遗忘 门和输出门,有效地处理了长期依赖问题,使得网 络能够更好地捕捉和保留长时间跨度的信息。 LSTM 神经网络模型如图1所示。

LSTM 神经网络的关键是单元状态,其利用门 控机制有选择的记忆或者遗忘相关控制信息^[22-23]。 该模型相应的输入输出可以表示为:

$$f_t = \sigma \left(W_f \cdot \left[h_{t-1}, x_t \right] + b_f \right)$$
(3)

$$l_t = O\left(W_i \cdot \left[n_{t-1}, x_t\right] + D_f\right)$$

$$C'_t = track \left(W_i \left[1, \dots, 1\right] + L_i\right)$$
(5)

$$C_t = \tanh\left(W_c \cdot \lfloor n_{t-1}, x_t \rfloor + b_c\right) \tag{5}$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot C_t' \tag{6}$$

$$o_t = \sigma \Big(W_{\rm o} \cdot \big[h_{t-1}, x_t \big] + b_{\rm o} \Big) \tag{7}$$

$$h_t = o_t \cdot \tanh\left(C_t\right) \tag{8}$$

式中: x_t 为当前时刻输入信息; h_{t-1} 为上一时刻的隐藏状态; tanh 为双曲正切激活函数; h_t 为传递到下一时刻的隐藏状态。





本文所使用LSTM神经网络模型的输入层神经 元个数为 16,输出层神经元个数为 1,模型包含 1 个全连接层,1 个 LSTM 隐藏层的神经网络,其 中,隐藏层的隐藏神经单元个数为 10。将经 Prophet 模型进行时序特征提取的高频分量输入LSTM 神经 网络模型展开预测分析和拟合优化,得到更加精确 可靠的高频分量预测结果。

1.4 Prophet 模型

Prophet 是 2017 年提出的一种集成时间序列分 解和预测功能的建模方法^[24]。Prophet 模型通过拟合 历史时序数据的变化趋势,分析趋势、周期性以及 节假日等相关因素,对时序数据进行周期性拟合, 然后,Prophet 将这些拟合结果整合,生成原始时序 数据的预测值。与其他时间序列算法相比,Prophet 模型对于缺失值和异常值的处理更加有效。此外, Prophet 还提供了灵活的机制来针对性地训练节假日 或特殊日期的影响,从而提高预测的准确性。

综合能源系统负荷序列具有复杂多变、随机性 强等特点。因此,本文通过 Prophet 模型检测综合 能源系统电负荷数据的趋势特征、周期特征和节假

日特征,以提供更有规律的输入特征,简化数据复 杂性并提升负荷预测的可解释性。

Prophet 模型充分考虑了时间序列常见的 4 个 影响因素,算法模型为:

$$y(t) = g(t) + s(t) + h(t) + \beta_t \tag{9}$$

式中: g(t)为趋势项,由原序列减去周期得到; s(t) 为周期项,表示负荷序列中的以周或者年为单位的 周期性变化; h(t)为节假日项,反映时间序列在节假 日受到的影响; β_t为误差项,服从高斯分布。

1.5 预测模型构建

基于VMD、Prophet模型、ARIMA模型和LSTM 神经网络的组合预测模型的构建步骤如下。

 1)特征构造 选取综合能源系统负荷预测序 列、温度、空气湿度、太阳辐射量等与综合能源系 统负荷预测关联性较大的特征作为输入,并将电力 系统负荷数据划分为训练集和测试集。

2) 模型训练 构建基于 VMD、Prophet 模型、 ARIMA 模型和 LSTM 神经网络的组合预测模型。 设置模型各项超参数,学习率为 0.001,学习率下 降因子为 0.1,预测模型的训练批尺寸设为 8,迭代 次数为 1 000。

3)模型寻优和预测 训练集训练完成后,采用 Adam 优化器对预测模型相关参数进行寻优,寻优完成后使用测试集数据进行负荷预测。

2 特征因素相关性分析与预测流程

2.1 特征因素相关性分析

为量化特征因素和负荷序列的相关程度,本文 采用基于最大信息系数(MIC)法,选择强相关特 征作为预测模型的输入。MIC 不仅可以检测出线性 关系,还能够检测出各种非线性关系,具有很好的 普遍性^[25]。MIC 的计算公式为:

$$M_{\mathrm{IC},m} = \max_{[X_m][Y] \leq B} \frac{I[X_m;Y]}{\log_2\left(\min\left([X_m],[Y]\right)\right)}$$
(10)

式中: *M*_{IC,m} 为第 *m* 个特征对应的 MIC 值; *X*_m 和 *Y* 分别为第 *m* 个特征序列和电力负荷序列; *I*[*X*_m;*Y*] 为第 *m* 个特征和负荷之间的互信息参数; *B* 为大小 为[*X*_m][*Y*]的网格的上限。

本文中 MIC 的判断值为 0.3,当 MIC 的值大于 0.3 时为强相关, MIC 的值小于 0.3 时为弱相关。负 荷序列、温度、空气湿度、太阳辐射量、趋势特征、周期特征、节假日特征为本文待选的输入特征。综

合能源系统电负荷序列与其他 6 个特征因素的相关 性分析见表 1。

表1 综合能源系统电负荷相关性分析结果 Tab.1 Correlation analysis results of electric load of the IES

项目	温度	空气 湿度	太阳 辐射量	趋势 特征	周期 特征	节假日 特征
相关性	0.80	0.19	0.65	0.37	0.42	0.05

由表1可知,电负荷的强相关特征为温度、太 阳辐射量、趋势特征和周期特征。

2.2 负荷预测模型流程

本文所提基于 VMD、Prophet 模型、ARIMA 模型和 LSTM 神经网络的组合预测流程如图 2 所 示。首先,通过 VMD 来获取不同中心频率和较为 稳定的本征模态函数;接着,根据过零率值的大小 将不同模态分量分成高频和低频时序分量,并使用 Prophet 模型将高频分量进行时序特征提取;最后, 通过 ARIMA 模型对低频分量进行预测,使用 LSTM 神经网络模型对高频分量进行预测,将各自的预测 结果进行叠加得到最终的预测结果。



图 2 VMD-ARIMA-LSTM 模型预测流程 Fig.2 Prediction process of the VMD-ARIMA-LSTM model

3 算例分析

3.1 算例概况

本文的实验数据来源于亚利桑那州立大学校 园综合能源系统^[26],该系统由电、冷、热等能源组 成,综合能源系统电力负荷数据如图 3 所示,采样 周期为 1 h。选用 2021 年 6 月 1 日—2021 年 7 月 19 日的综合能源负荷数据,形成训练集和测试集. 其中,训练集由 2021 年 6 月 1 日—2021 年 7 月 11 日的共计 1 008 条负荷数据组成;测试集包括

2021 年 7 月 12 日—2021 年 7 月 18 日的共计 168 条负荷数据。



Fig.3 The measured data of electrical load series

3.2 数据归一化

本文对综合能源系统负荷数据进行归一化处 理以避免不同量纲带来的误差,归一化公式为:

$$x^* = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \tag{11}$$

式中: *x**∈[0, 1],为归一化后的值; *x*_{max}和 *x*_{min}分 别为负荷序列中的最大、最小值。

3.3 评价指标

本文通过均方根误差(δ_{RMSE})、绝对平均误差 百分比(δ_{MAPE})以及拟合优度 R^2 来评价预测模型 准确性的指标。 δ_{RMSE} 为预测值与实际值之差的平方 再均值的平方根,其值越小代表预测的性能越稳 定。 δ_{MAPE} 计算预测值和实际值的绝对平均误差, 其值越小模型预测精度越好。 R^2 为拟合优度值,其 值越大模型预测准确度越好。各指标的计算表达式 分别如下:

$$\delta_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^{n} (\hat{x}_i - x_i)^2}$$
 (12)

$$\delta_{\text{MAPE}} = \frac{100\%}{n} \sum_{i=1}^{n} \left| \frac{\hat{x}_i - x_i}{x_i} \right|$$
(13)

$$R^{2} = 1 - \frac{\sum_{i=1}^{n} (\hat{x}_{i} - x_{i})^{2}}{\sum_{i=1}^{n} (\bar{x}_{i} - x_{i})^{2}}$$
(14)

式中: n 为测试样本数; \hat{x}_i 为第i 个样本的预测值; x_i 为第i 个样本的实际值; \bar{x}_i 为样本平均值。

3.4 电负荷短期预测

VMD 是一种针对非线性信号的分解方法,它 可以在一定范围内将非线性信号分解为*K*个分量。 故确定分解的模态数量*K*是十分关键的。为了确定 分解后的模态数量*K*而计算每个本征模态分量的中 心频率 ω_i,结果见表 2。由表 2 可知,对于电负荷 序列,当模态数量 K 值为 5 时, ω_3 与 ω_4 的值较为 接近,此时出现了模态混叠现象,进而得到模态数 量 K 值为 4。

表 2 不同 K 值对应的中心频率 Tab.2 The center frequency according to different K values

负荷	K	中心频率						
		ω_1	ω_2	ω_3	ω_4	ω_5	ω_6	
电	3	0.14	37.45	592.46				
负	4	0.13	35.37	610.36	803.24			
荷	5	0.12	36.13	598.72	601.21	897.76		

电负荷序列变分模态分解结果如图 4 所示。由 图 4 可以计算出不同本征模态分量的过零率值,根 据过零率值的大小可知 IMF1、IMF2 和 IMF3 为高 频分量, IMF4 为低频分量。其中将 IMF4 低频分量 直接代入 ARIMA 预测模型进行预测。IMF1、IMF2 和 IMF3 等 3 个高频分量叠加为高频序列 P,将高 频序列 P 使用 Prophet 模型进行时序分解并代入 LSTM 神经网络预测模型进行迭代预测,综合预测 数值,得到预测结果。





图 4 电贝何受分候态分解结系 Fig.4 Decomposition results of the electrical load variational mode

为验证本文提出的组合预测模型在电负荷短 期预测中的有效性,选取单一 ARIMA 模型、单一 LSTM 模型、VMD-ARIMA(VA)模型、VMD-LSTM (VL)模型和 VMD-ARIMA-LSTM(VAL)模型作 为电负荷短期预测部分的对比方法进行消融实验, 各方法均采用相同的训练集和测试集,并以相同的 负荷、温度等特征作为输入。测试集中7月18日对 应的预测结果和相关指标如图5和表3所示。



图 5 消融实验结果对比 Fig.5 Comparison of ablation experiment results

表 3 消融实验误差对比 Tab.3 Comparison of ablation experiment errors

模型	$\delta_{ ext{MAPE}}$ /%	$\delta_{\rm RMSE}/{ m kW}$	R^2	计算 时间/s
ARIMA	27.63	554.42	0.74	63.2
LSTM	17.82	325.14	0.88	34.6
VMD-ARIMA	21.45	437.62	0.79	54.1
VMD-LSTM	14.97	221.74	0.91	28.6
VMD-ARIMA-LSTM	7.71	169.57	0.95	25.7
Prophet-VAL	4.85	136.74	0.98	22.9

由图 5 和表 3 可知,通过对负荷序列进行变分 模态分解得到低频和高频分量,再使用 Prophet 模 型对高频分量进行时序特征提取,不仅降低了负荷 序列的非平稳性,而且减少了一定的工作量,表现 出了更加优越的预测性能。结合负荷的高低频特性 进行高频分量和低频分量分别预测可以有效提高 预测精度,根据 Prophet 模型对高频分量进行时序 分解可以更好地分析高频分量的时序特征以减少 组合预测误差和优化模型结构。与其他 5 种预测模 型相比,Prophet-VAL 模型具有更好的预测性能。

3.5 多种预测模型对比

为验证本文所提模型在综合能源系统负荷预测中的优越性,本文选择2种机器学习方法——极限梯度提升(XGBOOST)、支持向量机(SVM)和3种深度学习方法——基于灰色关联度分析的长短时记忆神经网络(GRA-LSTM)、基于相空间重构结合双向长短时记忆神经网络(PSR-BiLSTM)、基于自适应局部迭代滤波分解-长短时记忆神经网络(ALIF-LSTM)作为对比模型。上述对比方法的输入与本文所提方法相同,对比方法针对综合能源系统电负荷的短期预测。不同模型在7月18日对应的预测结果和预测误差如图6和表4所示。



图 6 不同模型的预测结果 Fig.6 Prediction results of different models

表 4 不同模型的预测误差 Tab.4 Prediction errors of different models

模型	$\delta_{ ext{MAPE}}$ /%	$\delta_{\rm RMSE}/{\rm kW}$	R^2	计算 时间/s
SVM	23.55	493.86	0.76	1.4
XGBOOST	19.73	368.39	0.78	2.7
GRA-LSTM	8.45	177.49	0.92	22.6
PSR-BiLSTM	7.97	167.52	0.95	24.4
ALIF-LSTM	7.76	173.57	0.93	23.6
Prophet-VAL	4.85	136.74	0.98	22.9

由图 6 和表 4 对比可知,本文所提模型对电力 负荷的预测效果最佳,其他组合模型预测效果次 之,单一预测模型的预测效果最差。相比于单一预 测模型中预测效果最好的 XGBOOST, Prophet-VAL 在预测拟合优度提升了 25.641%,预测误差 δ_{MAPE}

和 δ_{RMSE} 分别降低了 75.418%和 62.882%。相比于组 合预测模型中预测效果最好的 PSR-BiLSTM, Prophet-VAL 在预测拟合优度提升了 3.158%, 预测 误差 δ_{MAPE} 和 δ_{RMSE} 分别降低了 39.147%和 18.374%。 以上算例证明:相对于对比模型,本文所提方法在 具有相似计算时间的同时,拥有更好的预测精度, 验证了所提基于 Prophet 模型的 VMD-ARIMA-LSTM 预测方法在综合能源系统短期负荷预测中具 有更高的准确性和适用性。

4结 论

本文提出一种面向综合能源系统短期负荷预测的基于 Prophet 的 VMD-ARIMA-LSTM 混合模型,明显增强了综合能源系统短期负荷预测性能,可得以下结论。

1) 融合 VMD 和 Prophet 模型降低了原始时序 数据的非平稳性,提高了时序数据质量。

2)考虑综合能源系统负荷序列高频分量的复杂性和非线性等特点,使用 Prophet 模型挖掘综合能源系统负荷序列高频分量的用电特性中,提取负荷序列高频分量中的时序特征。并将使用 Prophet 模型分解得到的相关时序特征作为输入特征,明显 提高所提模型的预测性能。

3)与其他传统机器学习和深度学习预测模型 对比,本文所提模型具有更高的预测精度和更优越 的预测性能。

本文所提方法未考虑实时电价等因素对负荷 预测带来的影响,且算法对极端值的处理并未达到 理想情况,原因是极端值偏离常规点的水平难以估 计,难以捕捉全部极端值。后续应考虑更多因素对 负荷数据的影响,研究如何更好地捕捉极端值,进 一步提高预测模型的通用性。

[参考文献]

- [1] 朱继忠,董瀚江,李盛林,等.数据驱动的综合能源系统负荷预测综述[J].中国电机工程学报,2021,41(23):7905-7924.
 ZHU Jizhong, DONG Hanjiang, LI Shenglin, et al. A review of data-driven load forecasting for integrated energy systems[J]. Proceedings of the CSEE, 2021,41(23):7905-7924.
- [2] JAHAN I S, SNASEL V, MISAK S. Intelligent systems for power load forecasting: a study review[J]. Energies, 2020, 13(22): 6105.
- [3] KHWAJA A S, ZHANG X, ANPALAGAN A, et al. Boosted neural networks for improved short-term electric load forecasting[J]. Electric Power Systems Research, 2017, 143: 431-437.

- [4] 李薇, 王鑫鹏, 许野, 等. 基于传递闭包的光伏短期功率组合预测方法研究[J]. 太阳能学报, 2023, 44(6): 265-274.
 LI Wei, WANG Xinpeng, XU Ye, et al. Research on short-term photovoltaic power combination prediction method based on transfer closure[J]. Proceedings of the CUS-EPSA, 2023, 35(6): 59-65.
- [5] 付文杰,李化,杨伯青,等.基于集合卡尔曼滤波与相空间重构的负荷预测方法研究[J].电力需求侧管理,2022,24(1):49-54.
 FU Wenjie, LI Hua, YANG Boqing, et al. Research on load forecasting method based on ensemble Kalman filter and phase space reconstruction[J]. Power Demand Side Management, 2022, 24(1):49-54.
- [6] 张功勋,姚方,曹赟. 基于 CNN-SVR 城市日负荷预测 机制[J]. 电气自动化, 2022, 44(5): 38-40.
 ZHANG Gongxun, YAO Fang, CAO Yun, et al. Urban daily load forecasting mechanism based on CNN-SVR[J].
 Electrical Automation, 2022, 44(5): 38-40.
- [7] 伍乙杰,黄文灏,赖仕达,等. 基于随机森林和双向长短期记忆网络的超短期负荷预测研究[J]. 电气自动化,2022,44(5):35-37.
 WU Yijie, HUANG Wenhao, LAI Shida, et al. Research on ultra-short-term load forecasting based on random forest and bidirectional long short-term memory network[J]. Electrical Automation, 2022, 44(5): 35-37.
- [8] 莫浩杰,彭勇刚,蔡田田,等. 一种基于时频特征融合 和极限学习机的非侵入式负荷识别方法[J]. 电工电能 新技术, 2023, 42(3): 85-96.
 MO Haojie, PENG Yonggang, CAI Tiantian, et al. A non-invasive load identification method based on time-frequency feature fusion and extreme learning machine[J]. Advanced Technology of Electrical Engineering and Energy, 2023, 42(3): 85-96.
- [9] 关圆新. 基于耦合 Prophet-PSO-GPR 组合模型的电力 负荷预测[D]. 太原:山西大学, 2023:1. GUAN Yuanxin. Power load forecasting based on coupled Prophet-PSO-GPR model[D]. Taiyuan: Shanxi University, 2023:1.
- [10] ALBERG D, LAST M. Short-term load forecasting in smart meters with sliding window-based ARIMA algorithms[J]. Vietnam Journal of Computer Science, 2018, 5: 241-249.
- [11] 罗权. 基于自适应卡尔曼滤波在气象影响下负荷预测[J]. 计算机测量与控制, 2020, 28(1): 156-159.
 LUO Quan. Load prediction under meteorological influence based on adaptive Kalman filter[J]. Computer Measurement and Control, 2020, 28(1): 156-159.

 [12] 滕爱国,单新文,李萌,等. 基于改进 SVR 的微网短期负荷预测研究[J]. 自动化与仪器仪表, 2020(12): 194-197.
 TENG Aiguo, SHAN Xinwen, LI Meng, et al. Research on short-term load forecasting of microgrid based on improved SVR[J]. Automation and Instrumentation,

2020(12): 194-197.
[13] ZHANG W, HUA H, CAO J. Short term load forecasting based on IGSA-ELM algorithm[C]//2017 IEEE International Conference on Energy Internet (ICEI). IEEE, 2017: 296-301.

 [14] 陆继翔, 张琪培, 杨志宏, 等. 基于 CNN-LSTM 混合 神经网络模型的短期负荷预测方法[J]. 电力系统自动 化, 2019, 43(8): 131-137.
 LU Jixiang, ZHANG Qipei, YANG Zhihong, et al. Short-term load forecasting method based on

- [15] YOUSAF A, ASIF R M, SHAKIR M, et al. An improved residential electricity load forecasting using a machine-learning-based feature selection approach and a proposed integration strategy[J]. Sustainability, 2021, 13(11): 6199.
- [16] 丁美荣, 张迎春. 融合序列分解与 Prophet 模型的时序 预测[J]. 计算机系统应用, 2023, 32(11): 294-301.
 DING Meirong, ZHANG Yingchun. Fusion sequence decomposition and temporal prediction of Prophet model[J]. Computer Systems Applications, 2023, 32(11): 294-301.
- [17] DING J, XIAO D, LI X. Gear fault diagnosis based on genetic mutation particle swarm optimization VMD and probabilistic neural network algorithm[J]. IEEE Access, 2020, 8: 18456-18474.
- [18] 于军琪, 聂己开, 赵安军, 等. 基于特征挖掘的 ARIMA-GRU 短期电力负荷预测[J]. 电力系统及其自 动化学报, 2022, 34(3): 91-99.
 YU Junqi, NIE Jikai, ZHAO Anjun, et al. Short-term power load forecasting of ARMI-GRU based on feature mining[J]. Proceedings of the CUS-EPSA, 2022, 34(3): 91-99.
- [19] 方娜,李俊晓,陈浩,等. 基于 CNN-GRU-MLR 的多 频组合短期电力负荷预测[J]. 计算机仿真, 2023, 40(1):118-124.
 FANG Na, LI Junxiao, CHEN Hao, et al. Multi-frequency combination short-term power load forecasting based on CNN-GRU-MLR[J]. Computer Simulation, 2023, 40(1): 118-124.
- [20] SHUMWAY R H, STOFFER D S. ARIMA models[M]//Time Series Analysis and its applications: with R examples. 2nd ed. Springer: 2017: 75-163.
- [21] 魏乐, 苏少忻, 房方, 等. 基于负荷预测的飞轮-火电 系统自动发电控制响应性能优化[J]. 热力发电, 2023, 52(5): 92-99.

WEI Le, SU Shaoxin, FANG Fang, et al. Optimization of automatic generation control response performance of flywheel-thermal power system based on load forecasting[J]. Thermal Power Generation, 2023, 52(5): 92-99.

- [22] 黄璜,张安安. 基于分解算法与元学习结合的综合能源系统负荷预测[J]. 电力系统自动化,2024,48(10):151-160.
 HUANG Huang, ZHANG Anan. Integrated energy system load forecasting based on decomposition algorithm and meta-learning[J]. Automation of Electric Power Systems, 2024, 48(10):151-160.
- [23] 张宇晨, 姜雪松, 李春伟, 等. 基于 Bootstrap 误差修 正的电力负荷短期预测深度学习模型[J]. 热力发电, 2023, 52(3): 121-129.
 ZHANG Yuchen, JIANG Xuesong, LI Chunwei, et al. Deep learning model for short term power load prediction based on Bootstrap error correction[J]. Thermal Power Generation, 2023, 52(3): 121-129.
- [24] 郇嘉嘉,李代猛,杜云飞,等.基于 Prophet 算法和 Blending 集成学习的实时负荷中期预测[J]. 电力自动 化设备, 2024, 44(4): 178-183.
 HUAN Jiajia, LI Daimeng, DU Yunfei, et al. Real-time load intermediate prediction based on Prophet algorithm and Blending integrated learning[J]. Electric Power Automation Equipment, 2024, 44(4): 178-183.
- [25] 张河宜,周毅,张军,等. 基于 MIC-LightGBM 的综合 能源系统多元负荷预测[J]. 电气时代, 2023(12): 51-53.
 ZHANG Heyi, ZHOU Yi, ZHANG Jun, et al. Multivariate load forecasting of integrated energy system based on MIC-LightGBM[J]. Electric Age, 2023(12): 51-53.
- [26] Arizona State University. Campus metabolism[EB/OL]. (2023-11-23) [2023-12-01]. http://cm.asu.edu/.

(责任编辑 杜亚勤)